



无线知识驱动的大规模 MIMO 信道估计

张四海^{1,2*}, 林嘉树¹, 徐亚梅¹, 赵明¹, 朱近康³

1. 中国科学技术大学中国科学院无线光电通信重点实验室, 合肥 230026

2. 中国科学技术大学微电子学院, 合肥 230026

3. 中国科学技术大学个人通信与扩频实验室, 合肥 230026

* 通信作者. E-mail: shzhang@ustc.edu.cn

收稿日期: 2022-04-30; 修回日期: 2022-07-01; 接受日期: 2022-08-17; 网络出版日期: 2023-04-11

科技部重点研发项目 (批准号: 2022YFB2902302)、安徽省自然科学基金 (批准号: 2208085MF159)、中国科学技术大学重要方向培育基金 (批准号: KY2100000115) 和华为技术有限公司无线研究创新项目 (批准号: FA2019051101) 资助

摘要 大规模多输入多输出 (multiple-input multiple-output, MIMO) 技术能够显著提升无线通信系统的能量效率和频谱效率, 其关键前提是获取精确的信道状态信息, 然而导频复用造成的导频污染问题严重影响信道估计精度, 成为制约大规模 MIMO 系统性能的核心难题. 本文提出无线知识驱动的大规模 MIMO 信道估计模型, 基于信道海图技术挖掘用户在角度域空间中的近邻关系作为无线信道知识, 设计基于无线知识驱动的卷积神经网络 (convolutional neural network, CNN) 信道估计器 (WKD-CNN) 提高信道估计精度. 研究表明, 在不同信噪比 (signal-to-noise ratio, SNR) 下, 天线数、导频污染程度、训练集大小对所提方法的信道估计性能均有重要影响. 仿真结果表明, WKD-CNN 在高信噪比区域的归一化均方误差相较于传统信道估计算法、基于多层感知机 (multilayer perceptron, MLP) 和无信道海图知识驱动卷积网络的信道估计方法均明显降低.

关键词 大规模 MIMO, 信道海图, 信道估计, 知识驱动, 机器学习

1 引言

大规模多输入多输出 (multiple-input multiple-output, MIMO) 技术是第五代移动通信系统 (5th generation mobile communication system, 5G) 的主流技术, 是当今无线通信领域的重要方向^[1]. 大规模 MIMO 在基站侧使用大量可独立控制天线器件的无线通信系统^[2,3], 其优势主要在于: (1) 当基站侧天线数量趋于无限大时, 基站和不同用户间的信号传输信道矢量将逐渐正交化, 此时信道传输过程中的高斯 (Gauss) 噪声与用户间干扰逐渐消失^[4]. (2) 基站侧的庞大天线阵列可有效挖掘无线通信系统空间资源的潜力, 增加系统的空间自由度, 大幅度提高系统的频谱效率^[5]. (3) 多天线阵列能够将传输信号的能量集中到范围更小的空域中, 从而显著提升通信系统的能量利用效率^[6]. 大规模 MIMO 技

引用格式: 张四海, 林嘉树, 徐亚梅, 等. 无线知识驱动的大规模 MIMO 信道估计. 中国科学: 信息科学, 2023, 53: 758–771, doi: 10.1360/SSI-2022-0173
Zhang S H, Lin J S, Xu Y M, et al. Wireless knowledge driven channel estimation in massive MIMO (in Chinese). Sci Sin Inform, 2023, 53: 758–771, doi: 10.1360/SSI-2022-0173

术面临的最主要挑战是导频污染,是限制大规模 MIMO 技术在实际工程应用中发挥性能增益的瓶颈.导频污染指由于信道状态仅在较短的相干时间间隔内维持恒定,所有基站需要同步地在一个相干时间间隔内完成信道估计,无法给所有用户分配正交导频,因此目标用户的信道估计结果会受复用相同导频的用户影响的现象.即使扩大基站侧天线阵列规模,导频污染现象也仍然存在.

基站侧需要获取精确的信道状态信息用于执行预编码、信号检测等后续信号处理步骤,因此精确的信道估计结果是充分发挥大规模 MIMO 系统性能的前提与保障.基于导频的传统信道估计方法按照一定的估计准则一次性或逐步地确定待估计参数的值,如最小二乘法 (least square, LS)、最小化均方误差法 (minimum mean square error, MMSE). LS 算法不考虑信号传输过程中的噪声影响并直接应用最小二乘估计准则,算法复杂度低,但估计精度随信噪比下降而严重恶化^[7]. MMSE 算法可获得高精度的信道估计结果,但推导过程涉及矩阵求逆等运算,计算复杂度极高^[8].利用无线传输信道统计特征的基于导频的信道估计方法利用数据传输部分信号互相关性低的特点,使用部分解码数据辅助信道估计以去除导频污染影响,在高信噪比下的误码率仅有 10^{-5} ^[9].基于传统 MMSE 算法利用 Turbo 均衡解码数据的去导频污染信道估计算法仅将目标蜂窝小区的大尺度衰落系数看作先验条件,并使用仿真数据集验证所提方法在不同场景参数设置下的适用性,该方法在高信噪比区域的均方误差接近 MMSE 算法^[10].还可利用 LS 信道估计结果对信道自相关矩阵进行估计,基于该估计值降低 MMSE 算法的计算复杂度^[11].但上述方法均依赖基站侧难以获取的信道统计特征,因此应用性有限.蜂窝小区间相互协作也可降低大规模 MIMO 场景下的导频污染影响,如小区各基站协作进行信道信息交换的联合导频分配^[12,13],基于空间滤波的鲁棒信道估计方法^[14]等,但此类采用小区间协作的基于导频的信道估计方法需要高昂的系统开销.近年来,基于深度学习的大规模 MIMO 信道估计方法发展迅速.针对大规模 MIMO 系统导频污染的基于深度学习的上行链路信道估计框架利用角度域的稀疏结构特性将整个角空间分割成许多小区域,为每个区域分别离线训练神经网络,当基站侧天线规模到达 256 时,该方法的信道估计误差接近 0.001^[15].适用于大规模 MIMO 通信场景的基于机器学习信道估计使用各种信噪比下的接收信号和波达角样本集构建深度神经网络的数据集,利用神经网络学习大规模 MIMO 传输信道的统计特征和角度域的空间关系,可实现高精度的波达角估计和信道估计^[16].将波束域空间的信道估计问题转换为稀疏信号重构问题的基于导频的高斯混合近似消息传递信道估计算法,使用高斯混合模型描述毫米波信号传播特性,基于稀疏性等信道先验特征改进传统的近似消息传递神经网络,当网络深度大于 10 时,其归一化均方误差降低至 7×10^{-3} ^[17].一种基于深度压缩感知的信道估计网络首先预测波束空间的信道幅度,然后根据获得的波束空间信道数目重建信道,在信道估计结束后,一种基于深度学习量化相位的混合预编码神经网络用于混合预编码设计,所提的基于深度学习的信道估计方法性能均优于现有方案^[18].基于机器学习的两阶段信道估计方法包括基于机器学习的噪声特征提取和初步信道估计阶段,以及深度网络数据辅助的估计结果校正阶段,也可降低导频污染的影响^[19].

传统机器学习方法求解无线通信领域问题时,往往不依赖具体的领域场景和相应的数学模型,仅利用深度神经网络的强大非线性拟合能力以解决相应问题,通过构建输入空间 $\mathcal{X}$ 到输出空间 $\mathcal{Y}$ 的映射,在参数空间寻找使得误差最小的最优解.但无线通信场景的复杂性大大增加构建输入与输出之间精确映射的难度,因此需要增加神经网络的深度.随着神经网络深度不断增加,可能出现后部隐藏层梯度指数级增加、前部隐藏层更新停滞、网络收敛困难等问题,使得训练开销不断提高.另外,暴力拟合输入数据与输出数据之间的映射关系,也难以获得较好的泛化能力.模型驱动机器学习的基本思路是:基于传统处理算法的迭代过程设计深度神经网络,网络训练的目标是找到影响算法性能的合适参数,有效提升学习性能,其主要不足是应用范围较小^[20,21].目前已有较多如何将知识与机器学习结合的

工作以提升机器学习的鲁棒性、可解释性等^[22, 23], 主要研究知识的来源、知识的表示形式以及知识与机器学习的结合形式. 知识驱动的机器学习模型 (knowledge-driven machine learning, KDML) 被应用于解决无线通信中的信道估计问题, 在传统机器学习的网络训练流程中增加通信知识处理, 改变学习模块的输入空间, 将复杂的映射问题转化为去噪或时间序列预测问题, 从而降低输入数据集的特征维度和学习模块的训练开销, 实验结果表明知识驱动的机器学习方法的信道估计均方误差在低信噪比区间比 LS 算法降低 2 个数量级^[24]. 本文进一步拓展该工作, 引入无线信道知识的作用, 考虑信道的用户空间相关性特征, 具体而言, 用户的波达角区间是否重叠影响用户的受导频污染程度, 与信道估计结果密切相关. 基于上述思想, 本文提出基于信道海图知识驱动的机器学习信道估计方法, 信道海图从无线信道统计特性中提取有效特征, 利用无监督降维方法将该特征映射到低维空间上获得信道海图, 海图上用户点的相对位置可以反映用户在真实世界中角度域的近邻关系^[25]. 用户的角度域信息与导频污染存在相关性, 通过将低维信道海图矩阵和无线通信知识结合驱动神经网络学习大规模 MIMO 系统下的多径空间相关信道, 从而提升神经网络信道估计器的估计精度和神经网络的可解释性.

本文针对大规模 MIMO 系统中的导频污染问题提出基于信道海图知识驱动的卷积神经网络 (convolutional neural network, CNN) 信道估计方法, 针对多径空间相关信道模型中用户受导频污染程度与用户在角度域空间相关性具有联系的特性, 通过计算信道协方差矩阵、缩放弥补失真、提取角度域特征、主成分分析降维等步骤构建信道海图以感知用户在角度域的近邻关系, 引入知识驱动机器学习方法构建卷积神经网络, 学习 LS 粗估计与原始信道矩阵之间的映射关系, 并进一步将信道海图作为辅助信道知识输入进行调优. 本文的主要贡献为, 提出无线知识驱动的大规模 MIMO 信道估计方法, 进一步引入无线环境知识, 和无线通信知识共同驱动机器学习. 针对大规模 MIMO 系统中的导频污染问题, 仿真实验表明所提方法优于 LS 和 MMSE 传统信道估计算法, 可有效提升大规模 MIMO 系统中的信道估计精度. 所提方法仅使用轻量级的网络架构, 便优于基于多层感知机的信道估计方法性能. 同时相较于不使用无线环境知识信息的 CNN 信道估计算法, 所提方法也有一定程度的性能改善.

2 系统模型

本节介绍所研究的通信系统模型, 包括大规模 MIMO 场景设置、无线信道模型、该通信场景中的导频污染问题.

2.1 大规模 MIMO 通信场景

本文考虑的大规模 MIMO 通信系统如图 1 所示, 包括 L 个蜂窝小区完全覆盖的区域, 在每个小区中心处配备均匀线阵且天线数为 M 的基站用于小区信号传输, 每个小区中随机均匀分布 K 个用户且每个用户均配置单根天线, 基站天线数与每个小区用户数满足关系 $M \geq K$, 在上行链路导频传输阶段, 用户向基站发送小区内正交的导频. 假定第 l 个小区中的第 k 个用户与第 j 个基站基于多径空间相关信道模型^[26], 其上行链路信道矢量如下:

$$\mathbf{h}_{j,l,k} = \frac{1}{\sqrt{P_{j,l,k}}} \sum_{p=0}^{P_{j,l,k}-1} \mathbf{a}(\theta_{j,l,k,p}) \alpha_{j,l,k,p} \sqrt{\beta_{j,l}}, \quad (1)$$

其中, $P_{j,l,k}$ 表示多径分量数, $\alpha_{j,l,k,p} \sim \mathcal{CN}(0, 1)$ 描述基站与终端间相对运动造成的小尺度衰落, $\beta_{j,l}$ 描述无线信道传播过程中的大尺度衰落, 主要包括路径损耗与阴影效应. $\theta_{j,l,k,p} \sim \mathcal{U}(\theta_{j,l,k,p}^n + \sqrt{3}\sigma, \theta_{j,l,k,p}^n - \sqrt{3}\sigma)$ 由第 l 个小区中的第 k 个用户与第 j 个基站之间的方向角和偏离角 σ 组成. 阵列响应矢量




图 1 大规模 MIMO 系统模型

Figure 1 Massive MIMO system model

$\mathbf{a}(\theta) = [1, e^{j2\pi \frac{d}{\lambda} \sin(\theta)}, \dots, e^{j2\pi \frac{d}{\lambda} \sin(\theta)(M-1)}]^T$. 值得注意的是, 本文中的大尺度衰落参数 $\beta_{j,l}$ 和第 l 个小区第 k 个用户与第 j 个基站间的直接距离 $D_{j,l,k}$ 相关:

$$\beta_{j,l} = \sum_{k=0}^{K-1} \frac{\rho_{j,l} D_{j,l,k}^{-1}}{K}, \quad (2)$$

其中, $\rho_{j,l}$ 为功率控制参数, 用以区分目标小区与干扰小区之间的信号衰减.

2.2 导频污染分析

大规模 MIMO 系统中, 基站需要在一个相干时间间隔内完成信道估计, 必须对分配给用户的导频长度进行限制, 不同小区间用户进行导频复用. 本文假设仅在小区内提供与本小区用户数相同的长度为 τ 的正交导频 Φ , 而 L 个小区间则复用完全相同的导频. 则第 l 个基站处接收得到上行链路信号如下式所示:

$$\mathbf{Y}_l = \sum_{i=0}^{L-1} \mathbf{H}_i \Phi + \mathbf{W}_l, \quad (3)$$

其中, 使用 Hadamard 矩阵构造的归一化正交导频矩阵 $\Phi = [\phi_1, \dots, \phi_K]^T \in \mathbb{C}^{K \times \tau}$ 满足 $\Phi^H \Phi = \mathbf{I}_K$. $\mathbf{W}_l \in \mathbb{C}^{M \times \tau}$ 表示基站侧的加性高斯白噪声.

不失一般性地, 本文将第 i 个小区看作信道估计的目标小区, 将其余 $L-1$ 个复用相同导频序列的小区视作干扰小区. 则第 i 个基站处的 LS 信道估计结果如下式所示:

$$\hat{\mathbf{H}}_i^{\text{LS}} = \mathbf{Y}_i \Phi^H = \mathbf{H}_i + \sum_{l=0, l \neq i}^{L-1} \mathbf{H}_l + \mathbf{W}_l \Phi^H, \quad (4)$$

其中, $\mathbf{H}_l = [\mathbf{h}_{l,0}, \dots, \mathbf{h}_{l,K-1}] \in \mathbb{C}^{M \times K}$. 信道矩阵 $\mathbf{H}_l$ 中元素 $\mathbf{h}_{l,k} \in \mathbb{C}^{M \times 1}$ 表示第 l 个小区中第 k 个用户与第 i 个基站之间的信道矢量. 从上式中可以明显看出, 尽管每个用户发送的导频序列与同小区其




图 2 (网络版彩图) 无线知识驱动机器学习模型结构示意图

Figure 2 (Color online) The framework of wireless knowledge-driven machine learning model

他用户正交, 但第 i 个小区中第 k 个用户的信道估计受到其余 $L-1$ 个小区中复用相同导频用户的干扰. 即使天线数量增加, 这种小区间干扰也不会消失, 即导频污染.

此外, 当基站天线的数量 M 趋于无穷大时, 具有非重叠波达角区间的用户的阵列响应矢量相互正交, 此时信道估计的最小均方误差 ε^P 取得最小值^[27]:

$$\varepsilon^P = \sum_{k=1}^K \text{tr} \left\{ \mathbf{R}_k - \mathbf{R}_k \left(\mathbf{R}_k + \frac{1}{\rho^P \tau} \mathbf{I} \right)^{-1} \mathbf{R}_k \right\}, \quad (5)$$

$$\theta(\mathbf{R}_i, \mathbf{R}_j) = \arccos \frac{\text{tr}\{\mathbf{R}_i^H \mathbf{R}_j\}}{\|\mathbf{R}_i\|_F \|\mathbf{R}_j\|_F} = \arccos \frac{\text{tr}\{\mathbf{R}_i \mathbf{R}_j\}}{\|\mathbf{R}_i\|_F \|\mathbf{R}_j\|_F} = \pi/2, \quad (6)$$

其中, $\mathbf{R}_k = \mathbb{E}[\mathbf{h}_k \mathbf{h}_k^H]$ 表示第 k 个用户的信道协方差矩阵. 因此, 用户在角度域上的空间相关性, 即波达角区间的近邻关系能够反映用户遭受的导频污染影响程度, 用户波达角区间的重叠部分越大, 导频污染越严重. 导频污染是限制大规模 MIMO 系统通信性能提升的瓶颈, 因此亟需设计能够利用用户角度域空间相关性分离复用导频的干扰小区信号的大规模 MIMO 系统信道估计算法.

3 无线知识驱动的机器学习模型

无线知识是描述、理解和认识无线通信领域中涉及的所有问题的通用术语, 包括但不限于经典模型和算法^[24]. 无线知识驱动的机器学习模型有机结合无线领域知识和传统数据驱动机器学习模型, 从而降低机器学习方法复杂度, 简化神经网络结构, 并最终提升算法的可解释性与可靠性.

本文所提的无线知识驱动机器学习模型结构如图 2 所示. 在传统机器学习模型的基础上, 本文引入通信知识和信道知识构建无线知识模块驱动机器学习, 其中通信知识选择传统 LS 信道估计算法构建, 此处的 LS 算法不是对原始数据特征的提取和映射, 而是直接将机器学习输入从 $\langle \mathbf{X}, \mathbf{Y} \rangle$ 转换到输出空间中, 以解决无线通信领域中输入空间与输出空间具有明显差异导致构建二者之间映射难度增大的问题, 从而降低模型复杂度. 信道知识指反映收发端间信道的重要统计特征, 本文进一步引入信道知识为神经网络提供有效的特征参数并简化神经网络结构, 获得更加精确信道估计结果, 并提升机器学习模块的可解释性与可靠性. 本文利用信道海图技术构建信道知识模块, 信道海图技术利用无监督降

维方式将基站端获得的海量高维信道状态信息映射到低维空间, 保留了真实空间中用户的局部几何位置信息.

设 D 为原始空间的维数 (例如, 三维代表用户在实际空间中的位置坐标由 x, y, z 轴构成). 考虑配备 M 根天线的基站以及 K 个单天线用户组成的通信系统, 将映射得到的信道海图空间维度记为 D' , 则信道海图矩阵 $\mathbf{Z} = [\mathbf{z}_1, \dots, \mathbf{z}_N]$ 如下:

$$\begin{pmatrix} z_{11} & \cdots & z_{1K} \\ \vdots & \ddots & \vdots \\ z_{D'1} & \cdots & z_{D'K} \end{pmatrix},$$

其中, $\mathbf{z}_n = [z_{1k}, z_{2k}, \dots, z_{D'k}]$ 表示维度为 D' 的信道海图上第 k 个点在图中的坐标矢量, 其物理意义为 D' 维空间中的绝对位置. 以 $D' = 2$ 为例: $\mathbf{Z}_{1s}$ 表示第 s 个点在海图中第一个坐标轴的绝对坐标, $\mathbf{Z}_{2s}$ 表示第 s 个点在海图中第二个坐标轴的绝对坐标. 信道海图的构建目标为: 找到一组点 $\{\mathbf{z}_k\}_{k=1}^K$ 满足如下条件: 当 $d_x(\mathbf{x}, \mathbf{x}')$ 较小时,

$$d_z(\mathbf{z}, \mathbf{z}') \approx d_x(\mathbf{x}, \mathbf{x}'), \quad (7)$$

其中, $\mathbf{x}, \mathbf{x}' \in \mathbb{R}^D$ 为原始空间中两组不同的坐标, $\mathbf{z}, \mathbf{z}' \in \mathbb{R}^{D'}$ 为信道海图空间中两组不同的坐标. $d_x(\mathbf{x}, \mathbf{x}')$ 以及 $d_z(\mathbf{z}, \mathbf{z}')$ 为对距离 (或差异性) 的适当度量指标. 上式可以理解为当原始空间中的两个点差异性较小时, 海图空间也应该尽可能地还原这两点的这种相似性.

信道状态信息包含小区整体的几何位置信息, 构建信道海图以分析用户空间相关性, 首先需要从信道状态信息中提取合适的特征. 大规模 MIMO 系统的大尺度衰落特性可以从无线信道环境的二阶统计量中获取, 即信道协方差矩阵 $\mathbf{R}$ 携带有关大尺度衰落特性的信息 [25]. 此外, 假设多天线多径空间相关信道的统计特性变化相对较慢, 因此将信道的协方差矩阵 $\mathbf{R}$ 在基站侧视为已知, 目标小区可以通过小区间的协作获得其他小区的信道协方差矩阵信息 [28, 29]. 在实际中, 一般计算信道协方差矩阵 $\mathbf{R}$ 的方法为

$$\mathbf{R} = \frac{1}{T} \sum_{t=0}^{T-1} \mathbf{h} \mathbf{h}^H, \quad (8)$$

其中, T 为参与统计的信道样本数.

在无线通信系统中, 原始的信道状态信息实际上不是空间位置的最佳表示形式 [25]. 假设在无线通信系统中, 存在两个与基站相距较近的用户终端 Tx_A 和 Tx_B , 存在两个与基站相距较远的用户终端 Tx_C 和 Tx_D , 且 Tx_A 和 Tx_B 之间的距离小于 Tx_C 和 Tx_D 之间的距离. 由于多径相关信道中的大尺度衰落特性, Tx_C 和 Tx_D 的信道状态信息 $\mathbf{H}_C$ 和 $\mathbf{H}_D$ 的测量值将小于位于基站附近 Tx_A 和 Tx_B 的信道状态信息 $\mathbf{H}_A$ 和 $\mathbf{H}_B$ 的测量值. 若此时比较 Tx_C 和 Tx_D 之间的 Frobenius 距离 (或欧氏距离), 可能会得出 Tx_A 和 Tx_B 之间的距离大于 Tx_C 和 Tx_D 之间的距离的错误结论. 为了避免这种情况, 需要对信道协方差矩阵进行缩放, 从而弥补失真:

$$\widetilde{\mathbf{H}} = \frac{M^{\gamma-1}}{\|\mathbf{R}\|_F^\gamma} \mathbf{R} \quad \text{with} \quad \gamma = 1 + \frac{1}{2\sigma}, \quad (9)$$

其中, Frobenius 范数 $\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^2}$, σ 为调谐参数. 由于 $\gamma \geq 1$, 远离基站的协方差矩阵被放大, 而基站附近的协方差矩阵被衰减, 以此来补偿用信道状态信息表示空间位置信息的失真.




图 3 (网络版彩图) 无线知识驱动的 CNN 信道估计框架

Figure 3 (Color online) The framework of wireless knowledge-driven CNN channel estimation

为挖掘用户角度域中的近邻关系, 本文通过计算 $\widetilde{\mathbf{H}}$ 的离散傅里叶变换 (discrete Fourier transform, DFT) 对缩放后的信道协方差矩阵 $\widetilde{\mathbf{H}}$ 进行处理, 使得 $\widetilde{\mathbf{H}}$ 转换为角度域:

$$\mathbf{C} = \mathbf{D}\widetilde{\mathbf{H}}\mathbf{D}^H, \quad (10)$$

其中, $\mathbf{D}$ 为 M 阶的 DFT 矩阵并且满足 $\mathbf{D}\mathbf{D}^H = \mathbf{I}_M$. 经过非线性变换处理后的 $\mathbf{C}$ 能够更加简洁且更加有效地表示用户终端以及散射体对基站侧天线阵列的波达角信息 [26].

构建信道海图主要目标是将信道的高维信道状态信息转换为表征用户角度域中空间相关性的低维矩阵, 因此需要对式 (10) 中提取的信道特征 $\mathbf{C}$ 进行降维处理. 主成分分析 (principal component analysis, PCA) 方法是最广泛应用的无监督数据降维分析算法, 该方法首先将数据样本变量的均值和方差进行标准化预处理, 然后通过正交变换将原始数据样本映射到新空间中, 并使用由线性无关变量构成的近似数据代替. 在对数据进行降维的过程中, 对新变量即主成分所保留的信息量进行排序, 根据需要保留最重要的维度, 并去除相对冗余的维度 [30, 31]. 对数据执行 PCA 的流程既是发现数据的基本结构的过程, 也是对数据降维的过程.

4 基于信道海图知识驱动的 CNN 信道估计方法

本文提出基于信道海图知识驱动的 CNN 信道估计方法以解决大规模 MIMO 系统中的导频污染问题. 多径空间相关信道模型中目标小区用户承受的导频污染程度与用户在角度域的空间相关性有关, 而信道海图能够从高维信道状态信息中挖掘并保留用户角度域的近邻关系, 因此本文将信道海图作为辅助信道知识和包含导频污染的 LS 粗估计结果作为通信知识一起输入网络进行训练, 为卷积神经网络提供合适的无线通信特征信息, 即用户在角度域的空间相关性, 从而在较浅的网络深度条件下, 获得精确的信道估计性能, 并增加神经网络的可解释性.

基于信道海图知识驱动的 CNN 网络架构如图 3 所示, 将 LS 信道估计矩阵 $\mathbf{H} \in \mathbb{C}^{M \times K}$ 拆分为实部与虚部, 形成双通道矩阵并与信道海图矩阵 $\mathbf{Z} \in \mathbb{C}^{L \times K \times 2}$ 拼接 [32], 最终形成 $(M + L) \times K \times 2$ 的双通道矩阵输入到卷积神经网络中. 所提卷积网络依据功能可区分为 3 个部分. 第一部分是卷积网络的输入层, 由卷积层与批归一化 (batch normalization, BN) 层构成. 卷积核深度和该层输入通道数必须保持一致, 因此该卷积层包含 8 个 $5 \times 3 \times 2$ 的卷积核. 批归一化层用以调整神经网络的输出均值与

方差, 保证模型的非线性表达能力. 第 2~4 层为 CNN 的第二部分, 该部分包括由卷积层、激活函数 ELU (exponential linear units)、批归一化层构成的隐藏层和丢弃层 (dropout).

$$\text{ELU}(x) = \begin{cases} x, & x \geq 0, \\ \alpha(e^x - 1), & x < 0, \end{cases} \quad (11)$$

其中, 激活函数 ELU 集成 Sigmoid 函数和 ReLU (rectified linear units) 函数的特点, 左侧引入指数运算 e^x , 右侧引入线性变换. 其中左侧的指数部分使得 ELU 函数对噪声具有更强的抗干扰性, 而右侧线性部分避免将输入映射为极小值以解决梯度消失问题. 丢弃层在前向传播过程中将以指定概率随机中断网络层中部分神经元连接, 避免由网络过深和模型过复杂引起的过拟合问题. 最后一部分为输出层, 该层包含 8 个 $3 \times 3 \times 2$ 的卷积核, 确保网络输出为 $M \times K \times 2$ 的信道估计矩阵. 则各层神经网络的映射操作可表示为

$$\begin{cases} f_1 = \text{BN}(\theta_1 \otimes x_1), \\ f_2 = \text{ELU}(\text{BN}(\theta_2 \otimes x_2)), \\ f_3 = \text{Dropout}(x_3), \\ f_4 = \text{ELU}(\text{BN}(\theta_4 \otimes x_4)), \\ f_5 = (\theta_5 \otimes x_5), \end{cases} \quad (12)$$

其中, $\otimes$ 表示卷积操作, θ_n 表示第 n 层网络参数, x_n 表示第 n 层网络输入. 上述构建的神经网络架构可以从输入数据空间中利用卷积核提取用户间角度域空间相关性特征, 并通过优化网络的学习过程学习 LS 信道估计结果到精确信道的映射关系, 以提升神经网络的可靠性和可解释性.

5 实验设置与结果分析

5.1 系统参数与性能指标

本文通过仿真验证所提出的基于信道海图知识驱动的 CNN 信道估计方法, 研究不同信噪比条件下, 不同天线数、不同导频复用率、不同训练集大小对本方法的性能影响. 值得注意的是本实验中的信号衰减经过功率控制参数 $\rho_{j,l}$ 调整后, 目标小区大尺度衰落系数近似为 1, 干扰小区大尺度衰落系数近似为 0.1. 模型输入为包含导频污染的 LS 粗估计结果和信道海图, 模型输出即标签数据为不含导频污染的信道状态信息 (在实际工程中, 可以预先在仅包含目标小区用户的场景中采集该数据), 二者共同构成训练集与测试集. 本文提出的基于信道海图知识驱动的卷积神经网络深度以及训练轮数都远小于其他基于机器学习的信道估计文献中的相应设置.

本文实验设定的主要大规模 MIMO 系统和 CNN 信道估计器参数如表 1 所示. 需要说明的是, 所提方法的网络训练轮数被设置为 50, 但实验表明仅需要 40 轮训练即可收敛, 相比传统机器学习方法一般需要几百轮的训练轮数^[33], 本文模型降低了训练成本.

在本文的仿真实验部分, 采用归一化均方误差 (normalized mean square error, NMSE) 作为衡量信道估计方法的性能评价指标. 第 i 个小区第 k 个用户的平均 $\text{NMSE}_{i,k}$ 定义为

$$\text{NMSE}_{i,k} = \frac{1}{K} \sum_{k=0}^{K-1} E \left\{ \frac{\|\hat{\mathbf{h}}_{i,k}^{CC} - \mathbf{h}_{i,k}\|^2}{\|\mathbf{h}_{i,k}\|^2} \right\}. \quad (13)$$

表 1 通信系统参数和 CNN 参数

Table 1 Communication system parameters and CNN parameters

Communication system parameter		CNN parameter	
Parameter	Value	Parameter	Value
Number of users per cell (K)	8, 16, 32, 64	Depth	5
Number of antennas (M)	16, 32, 64, 128	Number of kernels	8, 16
Pilot length (τ)	8, 64	Optimiser	Adam
Radius of each cell (R)	300 m	Loss function	MSE
Number of paths (P)	3	Learning rate	0.01, 0.001
Number of cells (L)	7	Batch size	50
		Kernel size	(3×3) , (4×3) , (5×3)
		Epoch	50

5.2 基于机器学习的对比算法

本小节介绍后续实验中使用的基于机器学习对比算法的相关设置.

(1) **基于多层感知机 (multilayer perceptron, MLP) 的信道估计方法.** 本节实验部分训练一个基于 MLP 的信道估计器作为机器学习算法的参考基线. 基于传统机器学习的 MLP 信道估计器以包含导频污染的 LS 粗估计与不含导频污染的信道构建训练数据集, 利用神经网络的非线性拟合能力学习输入与输出之间的映射关系. 该 MLP 的网络深度与所提 WKD-CNN 相同, 由 4 层全连接网络隐藏层和 1 层丢弃层组成, 其中全连接网络层中的神经元个数分别为 8, 16, 8, 2, 与所提 WKD-CNN 相应网络层中的卷积核数量相同.

(2) **无信道海图知识驱动的 CNN 信道估计方法.** 为考察信道海图作为信道知识对所提 WKD-CNN 的增益效果, 本节实验训练一个仅使用通信知识的 CNN 信道估计器作对比^[24], 其模型输入为 LS 粗估计, 标签数据为不含导频污染的信道状态信息. 由于 CNN 和所提 WKD-CNN 输入维度不同, 因此二者的输入层网络架构有所差异, CNN 的输入层由 8 个 $3 \times 3 \times 2$ 的卷积核组成, 其余网络层结构以及网络深度与所提 WKD-CNN 保持一致, 以评估信道海图提取的用户角度域空间相关性作为信道知识在网络训练中的作用.

(3) **协方差矩阵知识驱动的 CNN 信道估计方法.** 本节实验额外设计使用协方差矩阵作为信道知识的 CNN 信道估计器以比较信道协方差矩阵和信道海图作为信道知识对网络的作用. 该信道估计器的输入为 LS 粗估计与信道协方差矩阵, 标签数据为不含导频污染的信道状态信息. 实验中构建深度为 5 和 10 的 CNN, 其中深度为 5 的 CNN 的网络层由尺寸为 $8 \times 3 \times 2$ 和 $3 \times 3 \times 2$ 的卷积核构成, 深度为 10 的 CNN 的网络层由尺寸为 $5 \times 3 \times 2$ 和 $4 \times 3 \times 2$ 的卷积核构成.

5.3 实验结果与分析

图 4 展示信道海图变换示意图 (基站天线数 M 为 128, 每小区随机分布 64 个单天线用户). 图 4(a) 使用不同颜色标记表示用户的空间位置分布关系, 用户之间的颜色标记越相近, 二者在小区中的实际物理距离越短. 图 4(a) 中系统获得的高维信道特征信息经过缩放、特征提取、降维后得到图 4(b) 所示的信道海图, 可以看出海图中用户相较于原始小区中的空间位置分布有所改变, 但海图中用户的颜色标记并没有出现明显的混叠现象, 仍然具有平缓渐变关系, 说明由用户信道协方差矩阵构造的信道海图能够有效保留用户在角度域的近邻关系.




图 4 (网络版彩图) 信道海图变换示意图. (a) 仿真生成的小区用户分布图; (b) 信道海图

Figure 4 (Color online) Schematic diagram of channel charting transformation. (a) The distribution map of cell users generated by simulation; (b) channel charting




图 5 (网络版彩图) 不同信噪比情况下各信道估计算法的 NMSE 性能 ($M = 128$, $K = 64$)

Figure 5 (Color online) NMSE performance of the channel estimation algorithm under different SNR ($M = 128$, $K = 64$)

图 5 为 $M = 128$, $K = 64$ 设置下所提方法和其他方法的 NMSE 性能比较. 首先由于导频污染的存在, 传统 LS 信道估计结果受到复用相同导频的其余小区信号的严重干扰, 其 NMSE 性能远远劣于其余方法. 本文提出的 WKD-CNN 方法在全信噪比区间中的 NMSE 性能均优于将小区大尺度衰落系数视为先验信息且高计算复杂度的传统 MMSE 信道估计算法, 证明所提方法具有良好的信道估计精度. 而 MLP 信道估计器的性能在高信噪比区域始终低于 MMSE 算法, 说明将包含多种信噪比的大量特征数据作为数据集时, 其仅是“暴力”拟合网络的输入和输出, 而非学习信道的统计特征, 难以适应复杂无线通信场景. 观察图 5 可知, 与 MMSE 相比, CNN 信道估计器在低信噪比下的性能增益比高信噪比下的增益大, 表明 CNN 通过挖掘 LS 估计的信道矩阵中的空间相关性主要去除了噪声干扰. 进一步, 对比仅使用 LS 粗估计作为网络输入的 CNN 信道估计器, 所提的 WKD-CNN 信道估计器在低信噪比区域和 CNN 信道估计器的性能基本相同, 但在高信噪比区域, WKD-CNN 的 NMSE 性能增益比 CNN 大并且增益稳定, 这是因为增加的信道海图知识可以反映目标小区用户信道和干扰小区用户信道在角度域的差异, 神经网络通过挖掘信道差异可以进一步降低导频污染.




图 6 (网络版彩图) 不同天线数情况下所提方法随信噪比变化的 NMSE 性能 ($K = 8$)

Figure 6 (Color online) NMSE performance of the proposed method with SNR for different numbers of antennas ($K = 8$)




图 7 (网络版彩图) 不同信道知识辅助的 CNN 信道估计器与传统算法随信噪比变化的 NMSE 性能 ($M = 16, K = 8$)

Figure 7 (Color online) NMSE performance of different channel knowledge-aided CNN channel estimators and traditional algorithms with SNR ($M = 16, K = 8$)

图 6 为 $K = 8$ 时不同天线数下 WKD-CNN 方法随信噪比变化的 NMSE 性能. 结果表明, 随基站天线数增加, 传统 LS, MMSE 算法和 WKD-CNN 方法的 NMSE 性能均提升, 而在不同天线数设置下, WKD-CNN 方法的性能在全信噪比范围内均优于相应的 LS, MMSE 算法, 证明本方法具有良好的泛化能力, 能够适应不同的通信场景.

图 7 为 $M = 16, K = 8$ 时不同信道知识辅助的 CNN 信道估计器与传统算法随信噪比变化的 NMSE 性能. 本实验中将信道协方差矩阵直接作为信道知识用于训练不同深度的 CNN 网络. 实验表明, 高维的协方差矩阵中包含冗余信息, 将其作为信道知识会增大网络模型的拟合难度并影响网络对通信知识的学习. 此外, 即使增加网络深度和模型复杂度也难以从庞大的信道协方差矩阵中获取有效的信道知识特征, 从而提升信道估计精度.

图 8 为固定 $M = 128$, 不同用户数下 WKD-CNN 方法随信噪比变化的 NMSE 性能. 本实验中可将正交导频数固定为 8, 而小区中用户数为 8, 16, 32, 64, 则对应的导频复用因子分别为 1, 1/2, 1/4, 1/8, 因此, 用户也会受到来自本小区复用相同导频用户的干扰, 且目标小区用户中大尺度衰落系数相同, 导频污染将随着本小区用户数量增多而愈发严重. 从图 8 中可看出, 在小区用户数远超过正交导频数的极端情况下, LS 和 MMSE 算法性能急剧下降, 而由于导频污染影响程度大幅提升, WKD-CNN 方法的 NMSE 性能在不同信噪比情况下变化较小, 但仍旧能够维持较高精度的信道估计性能. 在高信噪比区域 ($\text{SNR} > 15 \text{ dB}$), 导频复用因子为 1/2 时所提方法的 NMSE 性能与导频复用因子为 1 时 LS 算法的 NMSE 性能相近, 此时可节省 50% 的导频资源, 证明该方法在存在超多用户而导频资源紧张的通信场景中具有更加广阔的应用前景.

图 9 展示 $M = 128, K = 64$ 条件下, 不同训练集大小情况下所提方法随信噪比变化的 NMSE 性能. 随着训练集中的数据样本数量由 8000 增大为 32000, WKD-CNN 的 NMSE 性能逐步提升, 原因是随数据规模增大, 本方法能更好地挖掘信道状态信息与信道海图间的内在联系, 更加精确地拟合模型. 特别是, 即使当可使用的训练数据样本数量较少时, 所提方法性能仍然优于高计算复杂度的 MMSE 算法, 证明该方法在缺少数据样本场景下的有效性.




图 8 (网络版彩图) 正交导频数有限时不同用户数情况下所提方法的 NMSE 性能 ($M = 128$)

Figure 8 (Color online) NMSE performance of the proposed method under different numbers of users when the number of orthogonal pilots is limited ($M = 128$)




图 9 (网络版彩图) 不同训练集大小情况下所提方法随信噪比变化的 NMSE 性能 ($M = 128, K = 64$)

Figure 9 (Color online) NMSE performance of the proposed method with SNR under different training set sizes ($M = 128, K = 64$)

6 总结

本文为解决大规模 MIMO 系统中的导频污染问题, 提出无线知识驱动的大规模信道估计方法, 通过计算信道协方差矩阵、缩放弥补失真、提取角度域特征、PCA 降维等步骤构建信道海图感知用户在角度域的近邻关系. 我们设计合适的卷积神经网络, 将信道海图作为信道知识与 LS 信道粗估计作为通信知识送入网络进行训练, 解决传统机器学习方法在无线通信领域训练开销大以及可解释性低的弊端. 仿真实验表明, 信道海图能够有效感知用户空间近邻关系, 所提算法的 NMSE 性能优于传统 LS, MMSE 信道估计算法、基于 MLP 的信道估计器, 以及不使用信道海图的 CNN 信道估计器. 本文工作论证了基于信道海图的无线信道知识的作用以及无线知识驱动的信道估计方法的有效性和可行性.

参考文献

- Wang C X, Haider F, Gao X, et al. Cellular architecture and key technologies for 5G wireless communication networks. *IEEE Commun Mag*, 2014, 52: 122–130
- Marzetta T L. Noncooperative cellular wireless with unlimited numbers of base station antennas. *IEEE Trans Wireless Commun*, 2010, 9: 3590–3600
- Larsson E G, Edfors O, Tufvesson F, et al. Massive MIMO for next generation wireless systems. *IEEE Commun Mag*, 2014, 52: 186–195
- Hoydis J, Brink S T, Debbah M. Massive MIMO: how many antennas do we need? In: *Proceedings of the 49th Annual Allerton Conference on Communication, Control, and Computing (Allerton)*, 2011. 545–550
- Rusek F, Persson D, Lau B K, et al. Scaling up MIMO: opportunities and challenges with very large arrays. *IEEE Signal Process Mag*, 2013, 30: 40–60
- Boccardi F, Heath R W, Lozano A, et al. Five disruptive technology directions for 5G. *IEEE Commun Mag*, 2014, 52: 74–80
- de Figueiredo F A P, Cardoso F A C M, Moerman I, et al. Channel estimation for massive MIMO TDD systems assuming pilot contamination and frequency selective fading. *IEEE Access*, 2017, 5: 17733–17741
- Omar S, Ancora A, Slock D T M. Performance analysis of general pilot-aided linear channel estimation in LTE OFDMA systems with application to simplified MMSE schemes. In: *Proceedings of IEEE 19th International Symposium on Personal, Indoor and Mobile Radio Communications*, 2008. 1–6

- 9 Ma J, Ping L. Data-aided channel estimation in large antenna systems. *IEEE Trans Signal Process*, 2014, 62: 3111–3124
- 10 Ju M, Xu L, Jin L, et al. Data aided channel estimation for massive MIMO with pilot contamination. In: *Proceedings of 2017 IEEE International Conference on Communications (ICC)*, 2017. 1–6
- 11 de Figueiredo P F A, Lemes D A M, Dias C F, et al. Massive MIMO channel estimation considering pilot contamination and spatially correlated channels. *Electron Lett*, 2020, 56: 410–413
- 12 Yin H, Gesbert D, Filippou M, et al. A coordinated approach to channel estimation in large-scale multiple-antenna systems. *IEEE J Sel Areas Commun*, 2013, 31: 264–273
- 13 Qi C, Sun X, Deng Y, et al. QoS constrained pilot allocation scheme for massive MIMO systems. *IEEE Trans Veh Technol*, 2020, 69: 5661–5665
- 14 Gong Z, Li C, Jiang F. Pilot decontamination for cell-edge users in multi-cell massive MIMO based on spatial filter. In: *Proceedings of IEEE International Conference on Communications (ICC)*, 2018. 1–6
- 15 Gao J, Zhong C, Li G Y, et al. Deep learning-based channel estimation for massive MIMO with hybrid transceivers. *IEEE Trans Wireless Commun*, 2022, 21: 5162–5174
- 16 Huang H, Yang J, Huang H, et al. Deep learning for super-resolution channel estimation and DOA estimation based massive MIMO system. *IEEE Trans Veh Technol*, 2018, 67: 8549–8560
- 17 Wei X, Hu C, Dai L. Deep learning for beamspace channel estimation in millimeter-wave massive MIMO systems. *IEEE Trans Commun*, 2021, 69: 182–193
- 18 Ma W, Qi C, Zhang Z, et al. Sparse channel estimation and hybrid precoding using deep learning for millimeter wave massive MIMO. *IEEE Trans Commun*, 2020, 68: 2838–2849
- 19 Zhang Y, Mu Y, Liu Y, et al. Deep learning-based beamspace channel estimation in mmWave massive MIMO systems. *IEEE Wireless Commun Lett*, 2020, 9: 2212–2215
- 20 Borgerding M, Schniter P, Rangan S. AMP-inspired deep networks for sparse linear inverse problems. *IEEE Trans Signal Process*, 2017, 65: 4293–4308
- 21 Ito D, Takabe S, Wadayama T. Trainable ISTA for sparse signal recovery. *IEEE Trans Signal Process*, 2019, 67: 3113–3125
- 22 von Rueden L, Mayer S, Beckh K, et al. Informed machine learning—a taxonomy and survey of integrating prior knowledge into learning systems. *IEEE Trans Knowl Data Eng*, 2021, doi: 10.1109/TKDE.2021.3079836
- 23 Holzinger A, Kieseberg P, Weippl E, et al. Current advances, trends and challenges of machine learning and knowledge extraction: from machine learning to explainable AI. In: *Proceedings of International Cross-Domain Conference for Machine Learning and Knowledge Extraction*. Cham: Springer, 2018. 1–8
- 24 Li D, Xu Y, Zhao M, et al. Knowledge-driven machine learning and applications in wireless communications. *IEEE Trans Cogn Commun Netw*, 2022, 8: 454–467
- 25 Studer C, Medjkouh S, Gonultas E, et al. Channel charting: locating users within the radio environment using channel state information. *IEEE Access*, 2018, 6: 47682–47698
- 26 Ribeiro L, Leinonen M, Djelouat H, et al. Channel charting for pilot reuse in mMTC with spatially correlated MIMO channels. In: *Proceedings of IEEE Globecom Workshops (GC Wkshps)*, 2020. 1–6
- 27 You L, Gao X, Xia X G, et al. Pilot reuse for massive MIMO transmission over spatially correlated rayleigh fading channels. *IEEE Trans Wireless Commun*, 2015, 14: 3352–3366
- 28 Sanguinetti L, Bjornson E, Hoydis J. Toward massive MIMO 2.0: understanding spatial correlation, interference suppression, and pilot contamination. *IEEE Trans Commun*, 2020, 68: 232–257
- 29 Muppirisetty L S, Wymeersch H, Karout J, et al. Location-aided pilot contamination elimination for massive MIMO systems. In: *Proceedings of IEEE Global Communications Conference (GLOBECOM)*, 2015. 1–5
- 30 Pearson K. On lines and planes of closest fit to systems of points in space. *London Edinburgh Dublin Philos Mag J Sci*, 1901, 2: 559–572
- 31 Hotelling H. Analysis of a complex of statistical variables into principal components. *J Educational Psychol*, 1933, 24: 417–441
- 32 Lin X, Zhang L, Jiang Y. Location aided intelligent deep learning channel estimation for millimeter wave communications. In: *Proceedings of IEEE/CIC International Conference on Communications in China (ICCC)*, 2020. 489–494
- 33 Jiang P, Wen C K, Jin S, et al. Dual CNN-based channel estimation for MIMO-OFDM systems. *IEEE Trans Commun*, 2021, 69: 5859–5872

Wireless knowledge driven channel estimation in massive MIMO

Sihai ZHANG^{1,2*}, Jiashu LIN¹, Yamei XU¹, Ming ZHAO¹ & Jinkang ZHU³

1. CAS Key Laboratory of Wireless-Optical Communications, University of Science and Technology of China, Hefei 230026, China;

2. School of Microelectronics, University of Science and Technology of China, Hefei 230026, China;

3. Personal Communication Network & Spread Spectrum Laboratory, University of Science and Technology of China, Hefei 230026, China

* Corresponding author. E-mail: shzhang@ustc.edu.cn

Abstract Massive multiple-input multiple-output (MIMO) technology can significantly improve the energy and spectral efficiencies of wireless communication systems. The key premise is to obtain accurate channel state information. However, pilot contamination caused by pilot reuse critically affects the channel estimation accuracy and is thus a core problem restricting the performance of massive MIMO systems. In this paper, a wireless knowledge-driven massive MIMO channel estimation model is proposed. Based on the channel chart technology, the neighboring relationship among users in the angular domain space is mined as wireless channel knowledge, and a convolutional neural network (CNN) channel estimator driven by wireless knowledge (WKD-CNN) is designed to improve the channel estimation accuracy. The research shows that under different signal-to-noise ratios, the number of antennas, the degree of pilot pollution, and the size of the training set significantly impact the channel estimation performance. The simulation results show that the normalized mean square error of WKD-CNN in the high signal-to-noise ratio region is reduced significantly compared with the conventional channel estimation algorithm, multilayer perceptron (MLP)-based channel estimation method, and CNN without channel charting.

Keywords massive MIMO, channel charting, channel estimation, knowledge-driven, machine learning